

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKI
TEHNOLOGIJA

Sveučilišni studij

KONTROLA PRISTUPA VOZILA POMOĆU
RAČUNALNOG VIDA

Diplomski rad

Dominik Martin Rukavina

Osijek, 2017.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 10.12.2017.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu diplomskog rada

Ime i prezime studenta:	Dominik-Martin Rukavina
Studij, smjer:	Diplomski sveučilišni studij Računarstvo
Mat. br. studenta, godina upisa:	D 774 R, 19.10.2015.
OIB studenta:	89715339536
Mentor:	Doc.dr.sc. Ratko Grbić
Sumentor:	
Sumentor iz tvrtke:	Igor Koržinek
Predsjednik Povjerenstva:	Doc.dr.sc. Emmanuel-Karlo Nyarko
Član Povjerenstva:	Dr.sc. Ivan Vidović
Naslov diplomskog rada:	Kontrola pristupa vozila pomoću računalnog vida
Znanstvena grana rada:	Procesno računarstvo (zn. polje računarstvo)
Zadatak diplomskog rada:	U okviru diplomskog rada potrebno je izraditi sustav za kontrolu pristupa/prolaska vozila koji se temelji na računalnom vidu. Kontrola pristupa provodi se prepoznavanjem registarskih oznaka u slikama koje se dobivaju pomoću kamere. Sustav je potrebno implementirati na ugradbenoj računalnoj platformi zasnovanoj na Linux OS-u. Osim programske podrške za prepoznavanje registarskih oznaka potrebno je izraditi i odgovarajuću bazu podataka i sučelje koje krajnjem korisniku omogućava pregled i administraciju sustava (dodavanje novih vozila, povijest pristupa i sl.) (sumentor Igor Koržinek, GlobalLogic, Zagreb)
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	10.12.2017.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****IZJAVA O ORIGINALNOSTI RADA**

Osijek, 15.12.2017.

Ime i prezime studenta:

Dominik-Martin Rukavina

Studij:

Diplomski sveučilišni studij Računarstvo

Mat. br. studenta, godina upisa:

D 774 R, 19.10.2015.

Ephorus podudaranje [%]:

1

Ovom izjavom izjavljujem da je rad pod nazivom: **Kontrola pristupa vozila pomoću računalnog vida**

izrađen pod vodstvom mentora Doc.dr.sc. Ratko Grbić

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

Sadržaj

1.	UVOD	1
2.	KONTROLA PRISTUPA VOZILA	3
2.1.	Općenito o postojećim ANPR sustavima	3
2.2.	Postojeći ANPR sustavi	4
2.2.1.	OpenALPR	4
2.2.2.	ARHungary	5
2.2.3.	Dahua Technology	5
2.2.4.	TitanHz Canada	5
2.3.	Problemi kod ANPR sustava	6
2.3.1.	Razlike u osvjetljenju	6
2.3.2.	Oštećenja i nečistoća registracijskih oznaka	6
2.3.3.	Pozicija kamere sustava	6
2.3.4.	Razlike u formatima registracijskih oznaka	7
2.3.5.	Sigurnost ANPR sustava	8
3.	SKLOPOVLJE PREDLOŽENOG RJEŠENJA	9
3.1.	Definiranje ANPR sustava	9
3.2.	Sastavljanje predloženog sustava	11
3.3.	Prikupljanje ulaznih podataka (fotografija)	12
4.	PROGRAMSKO RJEŠENJE ANPR SUSTAVA	13
4.1.	Predobrada ulazne fotografije	15
4.2.	Pronalaženje kandidata registracijske pločice	17
4.3.	Lokalizacija registracijske pločice	19
4.4.	Pronalaženje znakova na tablici	23
4.5.	Prepoznavanje znakova	25
4.6.	Provjera prava pristupa i administracija ANPR sustava	28
5.	REZULTATI	29

6. ZAKLJUČAK	35
LITERATURA	36
SAŽETAK.....	38
ABSTRACT	39
ŽIVOTOPIS	40
PRILOG	41

1. UVOD

Kontrola pristupa u današnjem svijetu dobiva sve veću pažnju. Kontroliraju se pristupi podacima, pristupi različitim prostorijama zgrade (npr. ulaz u trezor banke), pristupi garažama, parkinzima i slično.

Kontrola pristupa označava dobivanje ili odbijanje prava za korištenje (pristup) resursima. Pod korištenjem resursa podrazumijeva se korištenje nekog sustava, pristup podacima ili prostoriji i slično. Kontrola pristupa se obavlja pomoću sustava za utvrđivanje identiteta korisnika pomoću definiranih jedinstvenih značajki. Značajke mogu biti zaporke, *RFID* kartice i *tagovi*, biometrijska svojstva poput otiska prsta i drugo. Nakon utvrđivanja identiteta, ovisno o njegovim pravima, korisniku se omogućava pristup. Svi korisnici sustava uobičajeno su spremljeni u bazu podataka koja sadržava osnovne informacije o korisnicima i njihove jedinstvene značajke.

Kontrola pristupa vozila određenim dijelovima grada ili garažama često se provodi pomoću jedinstvenih značajki poput radio-frekvencijskih kartica ili radio frekvencijskih odašiljača. Nedostatak takvih sustava je što svaki korisnik mora dobiti uređaj, tj. karticu ili odašiljač pomoću kojega ga sustav identificira. Suvremeni sustavi kontrole pristupa vozila zasnivaju se na računalnom vidu odnosno prepoznavanju jedinstvene registracijske oznake. Takvi sustavi se nazivaju ANPR (engl. *Automated Number Plate Recognition*) sustavima.

U nastavku rada se izmjenjuju pojmovi registracijska oznaka i pločica gdje se pod pojmom registracijska pločica misli na fizičku pločicu, a pod pojmom registracijska oznaka na tekst zapisan na registracijskoj pločici. Također pojam prepoznavanje registracijske pločice odnosi se na prepoznavanje (pronalaženje) područja na slici koje predstavlja registracijsku pločicu dok pojam prepoznavanje registracijske oznake označava potpuno prepoznavanje registracijske oznake koje uključuje i prepoznavanje područja registracijske pločice.

Danas postoje razni sustavi koji izvršavaju zadatak automatskog prepoznavanja registracijskih oznaka, no oni se sastoje od skupih, najčešće nekomercijalnih komponenti koje svojim mogućnostima osiguravaju brzo i u velikoj mjeri točno prepoznavanje registracijske oznake.

Međutim cilj ovog rada je izraditi cjenovno pristupačan sustav s istom ulogom. Ideja je snimati prilaz rampi ili kontrolnoj točki s relativnom jeftinom kamerom te pomoću mikroračunala obrađivati video zapis s kamere odnosno prepoznavati registracijske oznake iz određenog okvira (engl. *frame*) videa.

Automatsko prepoznavanje registracijskih oznaka na slici najčešće se sastoji od niza algoritama kao što su: predobrada ulaznog okvira videa, algoritma za lokalizaciju registracijskih pločica, algoritma za razdvajanje znakova registracijskih oznaka i algoritma za optičko prepoznavanje znakova.

Cilj ovoga rada je razviti sustav za automatsku kontrolu pristupa vozila pomoću računalnog vida. Od sustava se zahtijeva prepoznavanje registracijskih oznaka u različitim vremenskim uvjetima, danju i noću, kao i u slučaju kada registracijska pločica nije snimljena pod idealnim kutom. Sustav treba biti implementiran na relativno jeftinom jedno-kartičnom računalu (engl. *Single Board Computer-SBD*) i jeftinoj kameri. U radu su postavljena ograničenja za rad s jednorednim registracijskim pločicama Republike Hrvatske. Također pretpostavlja se da vozilo miruje ili se kreće vrlo malom brzinom u trenutku snimanja fotografije.

Sustav je implementiran pomoću Raspberry Pi 3B SBC računala i Raspberry Pi NOIR kamere. Za optičko prepoznavanje znakova je korištena Tesseract biblioteka dok su preostali algoritmi implementirani u C++ programskom jeziku korištenjem gotovih metoda za obradu slike. Optičko prepoznavanje znakova podrazumijeva prepoznavanje znaka na temelju fotografije toga znaka.

Rad je podijeljen u 6 poglavlja. Drugo poglavlje daje uvod u sustave za automatsko prepoznavanje registracijskih oznaka na temelju računalnog vida, daje pregled postojećih sustava te predstavlja problematiku ANPR sustava. Treće poglavlje sadrži prijedlog sklopovskog rješenja sustava zasnovanog na Raspberry Pi računalnoj platformi. Četvrto poglavlje daje prijedlog programskog rješenja za ANPR sustav. Peto poglavlje predstavlja rezultate ostvarene s predstavljenim sustavom nakon čega slijedi zaključak.

2. KONTROLA PRISTUPA VOZILA

Kontrola pristupa vozila u današnjici postavlja sve veće zahtjeve. Pokušava se izbjeći podjela uređaja za identifikaciju poput radio-frekvencijskih kartica ili daljinskih upravljača koji zahtijevaju složeniju administraciju, ponekad i zaustavljanje ispred samoga ulaza te održavanje (npr. daljinski upravljači zahtijevaju redovnu promjenu baterija što predstavlja dodatan trošak za sustav). Svi takvi uređaji rade na način da odašilju jedinstvenu informaciju i na taj način identificiraju korisnika. Unazad nekoliko godina razvijaju se sustavi koji koriste jedinstvenu informaciju zapisanu na registracijskoj pločici te tako ne zahtijevaju dodatne uređaje i najčešće zaustavljanje samog vozila. Jedan sustav (računalo) pomoću kamere snima prilaz i provodi bezkontaktnu identifikaciju pomoću jedinstvene registracijske oznake koju najčešće posjeduju sva motorna vozila. Identifikacija se provodi optičkim prepoznavanjem znakova s registracijske pločice. Takvi sustavi u svijetu su poznati kao ANPR ili LPR (engl. *License Plate Recognition*) sustavi.

2.1. Općenito o postojećim ANPR sustavima

Od ANPR sustava najčešće se zahtijeva da radi u svim vremenskim uvjetima, danju i noću. Noćno snimanje je omogućeno pomoću infracrvenih iluminatora i kamera koje „vide“ infracrvenu svjetlost odnosno kamera koje nemaju ugrađeni infracrveni filter. Optički senzor kamere tako „osjeti“ valne duljine od 400 do 1000 nm. Uglavnom se koriste posebno razvijane kamere za ANPR uporabu s varifokalnim lećama. Varifokalna leća je sustav leća koji se mehanički podešava odnosno može se mijenjati fokus, uvećanje, te bistrina slike koja se dobiva kamerom. Takve kamere imaju posebne optičke senzore i dodatnu hardversko-softversku podršku u obliku čipa koji ulaznu fotografiju dodatno obrađuje kako bi se dobila slika što veće kvalitete i sa što više korisnih informacija za ovu specifičnu primjenu. Kamere s takvim sustavima mogu snimati vozila pri iznimno velikim brzinama i dalje zadržati jednaku kvalitetu slike, a time i količinu informacije na snimljenoj fotografiji. Kod takvih kamera zapravo ne dolazi do zamućenja što bi znatno otežalo prepoznavanje registracijske oznake. Snimljena fotografija se šalje na računalo koje se nalazi u sklopu sustava ili ponekad na udaljeno računalo koje obavlja obradu ulazne slike. Pod obradom slike podrazumijeva se izvođenje LPR algoritma odnosno izvođenje niza algoritama za prepoznavanje i lokaliziranje registracijske pločice te samo optičko prepoznavanje znakova u svrhu čitanja registracijske pločice. Računala u takvim sustavima najčešće obrađuju podatke na grafičko procesorskim jedinicama ili digitalnim signalnim procesorima kako bi omogućili što bržu izvedbu svih potrebnih algoritama. Sustavi su

najčešće povezani na Internet gdje je smještena baza podataka te je kroz više vrsta sučelja omogućena administracija podataka odnosno dodavanje i brisanje korisnika kao i postavljanje određenih razina prava korisnika. Kamera s odgovarajućim mikroračunalom je postavljena na prilaz, a računalo za obradu podataka se nalazi u samom sustavu ili postoji udaljeno računalo koje obrađuje podatke i sustavu s kamerom šalje samo odgovor na upit za pristup korisnika. Trenutno ne postoji sustav koji obavlja prepoznavanje registracijskih oznaka s preciznošću 100%. Razlog tomu je vrlo velik broj različitih situacija koje se mogu pojaviti, npr. zbog vremenskih uvjeta, prevelikog kuta snimanja, oštećenja ili zaprljanosti registracijske pločice, različite pozicije registracijske pločice i slično [1].

2.2. Postojeći ANPR sustavi

2.2.1. OpenALPR

Jedan od poznatiji sustava za kontrolu pristupa vozila pomoću registracijske oznake je OpenALPR. Sustav se temelji na softverskom rješenju koje obavlja prepoznavanje registracijskih oznaka na slici dobivenom bilo kojom IP (*Internet Protocol*) kamerom. Sustav se može izvoditi lokalno na osobnom računalu ili na njihovom udaljenom serveru. U oba slučaja tvrtka omogućava besplatno korištenje uz osiguravanje visoke točnosti prepoznavanja ali uz neka ograničenja (npr. postoji ograničen broj korištenja kao i ograničeno vrijeme zadržavanja podataka). Tvrtka također omogućava komercijalne verzije sustava uz nešto bolju podršku u vidu administracije i zadržavanja podataka. Sustav se sastoji od niza algoritama koji se izvode slijedno. Algoritmi su: detekcija mogućih kandidata registracijske oznake na ulaznoj fotografiji, binariziranje (pretvaranje u binarnu sliku s vrijednostima 0 ili 255) izdvojenog područja registracijske pločice, analiza i prepoznavanje mogućih znakova u izdvojenom području, pronalaženje rubova registracijske pločice, ispravljanje perspektive, izdvajanje znakova, optičko prepoznavanje znakova i kreiranje popisa mogućih registracijskih oznaka s pripadnim točnostima odnosno postotkom sigurnosti. Sustav izvodi pronalaženje tablice na temelju lokalnih binarnih uzoraka (engl. *LBP local binary patterns*) te provodi optičko prepoznavanje pomoću Tesseract biblioteke [2]. Više podataka o sustavu se može pronaći u [3].

2.2.2. ARHungary

Tvrtka ARHungary [4] proizvodi posebne kamere za namjenu prepoznavanja registracijskih oznaka u svrhu kontrole pristupa kao i pripadajući softver za obradu podataka. Kamere su opremljene visoko preciznim motoriziranim varifokalnim lećama 5.2-58.8 mm, infracrvenim diodama te digitalnim signalnim procesorom (engl. *Digital Signal Procesor*- DSP) koji upravlja kamerom i obrađuje podatke. Uobičajeno je ugrađen DSP koji radi na oko 400 MHz te je zasnovan na ucLinux operacijskom sustavu. Tvrtka proizvodi i uređaje bazirane na ANPR sustavima za nadzor brzine kretanja. Takvi sustavi su opremljeni istim sustavom leća, ali boljim optičkim senzorom koji se zasniva na drugom konceptu osvjetljavanja senzora pa je moguće snimati kvalitetnije fotografije vozila u kretanju i pri većim brzinama. Rješenje se bazira na tome da dvije kamere na određenim udaljenostima snimaju vozilo i na temelju proteklog vremena mogu odrediti brzinu kretanja vozila.

2.2.3. Dahua Technology

Tvrtka nudi rješenja za nadzor i kontrolu ulaza/izlaza kao i rješenja za pametni nadzor i upravljanje parkingom [5]. Rješenja su zasnovana na LPR principu odnosno identifikaciji korisnika pomoću prepoznavanja registracijske oznake. Rješenja uključuju sustave s kamerom i računalom za obradu podataka i komuniciranje sa središnjim centralnim sustavom te dodatnim sustavom senzora za detekciju vozila na ulazu ili izlazu. Prema njihovim tvrdnjama omogućavaju točno prepoznavanje registracijskih oznaka u mjeri $\geq 95\%$ u vremenu manjem od jedne sekunde. Također s posebnim inteligentnim softverom omogućavaju prepoznavanje registracijskih oznaka s vozila koja se kreću.

2.2.4. TitanHz Canada

Tvrtka TitanHz [6] proizvodi ANPR sustave za razna tržišta pa tako i za većinu europskih zemalja. Osiguravaju rad u svim uvjetima 24 sata na dan. Pri radu s talijanskim registracijskim pločicama osiguravaju točnost prepoznavanja registracijske oznake s mjerom $\geq 98.5\%$. Također postoji i rješenje koje radi za registracijske oznake na području RH. Sustav se zasniva na tome da je registracijska oznaka izrađena od reflektivnog materijala. Sustav provodi identifikaciju registracijske pločice pomoću algoritama danih u nastavku: lokalizacija registracijske pločice, izmjena perspektive i prilagođavanje veličine slike, normalizacija ulazne slike, segmentacija

znakova, optičko prepoznavanje znakova te provjera znakova na temelju određenih pravila propisanih za određenu državu. Tvrtka nudi dva tipa sustava, stacionarni namijenjen za kontrolu pristupa te mobilne za korištenje policije.

2.3. Problemi kod ANPR sustava

2.3.1. Razlike u osvjetljenju

Problemi za ANPR sustave svakako su vremenski uvjeti u kojima moraju raditi, odnosno različitosti ulaznih fotografija koje ovise o jačini osvjetljenja u tom trenutku. Na primjer, postoje velike razlike u količini informacije koja se nalazi na ulaznoj fotografiji snimljenoj u samo jutro, u podne, predvečer ili kasno navečer. Sve te razlike rezultat su različite jačine sunca i njegove zaklonjenosti oblacima ili drugim predmetima. Takvi problemi se mogu izbjeći automatskim prilagođavanjem vremena ekspozicije odnosno vremena izlaganja optičkog senzora svjetlosti. Naprednije kamere posjeduju mehanizme zasuna za propuštanje određene količine svjetlosti.


2.3.2. Oštećenja i nečistoća registracijskih oznaka

Jedan od većih problema prilikom prepoznavanja registracijske oznake su oštećenja ili nečistoća registracijske pločice koje mogu narušiti točnost prepoznavanja te identifikaciju korisnika. Također kao problem se javljaju montažni vijci na registracijskoj pločici ili drugi objekti koji djelomično zaklanjaju registracijsku pločicu. Ovisno o tome na čemu je sustav za prepoznavanje registracijske oznake zasnovan, nečistoća ili djelomično zaklanjanje može prouzročiti probleme u samom prepoznavanju registracijske oznake ili lokalizaciji registracijske pločice. Još jedan problem je brzina kretanja vozila koje se želi identificirati. Naime kako bi dobivena fotografija bila što bistrija, a time i veće vjerojatnost ispravnog prepoznavanja potrebno je koristiti posebne optičke senzore ili postaviti vrijeme ekspozicije na što je moguće manje no tada postoji mogućnost propuštanja nedovoljne količine svjetlosti na optički senzor pa fotografija ne sadržava dovoljnu količinu informacije za prepoznavanje registracijske oznake.

2.3.3. Pozicija kamere sustava

Ako je prevelika udaljenost između kamere i snimanog objekta postoji velika mogućnost za dobivanje fotografije s premalo relevantnih informacija jer je registracijska oznaka predstavljena s malim brojem elemenata slike. Problem udaljenosti je moguće riješiti korištenjem varifokalnih leća i posebnih algoritama koji optimiziraju i postavljaju parametre leće. Kvaliteta snimljene fotografije odnosno količina informacije koju ona sadrži ovisi i o kutu snimanja. Promatrajući iz

tlocrta, kut snimanja je kut između zamišljene normale registracijske pločice i smjera snimanja kamere kako je prikazano u nastavku (Sl.2.1).



Sl. 2.1. Prikaz kuta između kamere i registracijske pločice snimanog vozila

Ako je kut θ između objekta i kamere prevelik, može se dogoditi da rub registracijske pločice na fotografiji bude preklapljen elementima najbližeg znaka do ruba te je time znatno otežana lokalizacija registracijske pločice.

2.3.4. Razlike u formatima registracijskih oznaka

Ako se od sustava zahtijeva da radi za nekoliko država, što se najčešće i podrazumijeva, pojavljuju se problemi u različitim formatima odnosno dimenzijama registracijskih pločica. Na primjer, Republika Hrvatska izdaje dvoredne registracijske pločice za motorna vozila na četiri kotača koje odudaraju od ostalih registracijskih pločica koje se izdaju osobnim i teretnim vozilima. Također, u takvim slučajevima se pojavljuje i problem s različitim *fontom* na registracijskim pločicama. Registracijske pločice u RH tako na primjer koriste isti znak za nulu i veliko slovo o što može otežati točno prepoznavanje ako se ne zna korišteni format zapisa. Obične građanske registracijske pločice u RH sadržavaju ograničenja da prva dva znaka moraju biti slova i predstavljaju oznaku za grad, a ostali znakovi mogu biti niz od tri ili četiri znamenke nakon čega slijedi jedno ili dva slova (Sl. 2.2.a). Također, registracijska oznaka može biti sastavljena od najmanje tri do najviše pet slovnih znakova nakon čega ide jedan ili dva brojana

znaka (Sl.2.2.b) Također, registracijska oznaka može biti sastavljena od najmanje tri do najviše sedam znakova pri čemu su svi znakovi slova (Sl. 2.2.c) [7].



a)



b)



c)

Sl. 2.2. Primjeri različitih registracijskih oznaka u RH


2.3.5. Sigurnost ANPR sustava

Jedan od većih problema ANPR sustava su ranjivost odnosno mogućnost zavaravanja sustava od strane zlonamjernih korisnika. Ovisno o tome koliko je poznat način na koji sustav funkcionira moguće je namjerno ili slučajno zavarati sustav zaklanjanjem dijela ili čak cijele tablice. Kao mogućnost se javlja i namjerno iskrivljavanje znakova kao i namjerno oštećivanje registracijske oznake u svrhu lažne identifikacije ili izbjegavanja identifikacije. Navedeni problemi nisu razmatrani u ovome radu.

3. SKLOPOVLJE PREDLOŽENOG RJEŠENJA

3.1. Definiranje ANPR sustava

Sustav se sastoji od kamere (Raspberry Pi NoIR camera module V2) za snimanje scene i računala (Raspberry Pi 3B) za upravljanje kamerom (optičkim senzorom) i obradu podataka. Sustav s kamerom i odgovarajućim mikroračunalom bi trebao biti postavljen uz prometnicu ili prilaz na kojemu se vrši kontrola pristupa.



Sl. 3.1. Prikaz odnosa udaljenosti i kuta pod kojim je kamera postavljena

Vidljivo na slici 3.1. kut pod kojim je postavljena kamera ovisi o udaljenosti kamere od snimanog objekta. Kako bi ulazna slika sadržavala što više informacije potrebno je kameru postaviti tako da kut θ bude što je moguće manji čime se povećava udaljenost od objekta, a samim time se smanjuje količina korisne informacije na snimljenoj sceni za ovu specifičnu primjenu. Kako bi se održala jednaka količina relevantne informacije za ovaj specifičan problem s povećanjem udaljenosti, potrebno je koristiti leću za povećanje slike. U ovome radu je korištena *telephoto* leća s 2X uvećanjem.

Nakon istraživanja sa slikama scene snimljenim u spektru vidljive i infracrvene svjetlosti zaključeno je kako je scenu potrebno snimati isključivo u infracrvenom spektru pomoću infracrvenog propusnog filtera (engl. *IR pass*). Naime slike koje su snimljene u oba spektra (vidljivi i infracrveni) sadrže dosta irelevantnih informacija (rubovi svih objekata su jasno raspoznatljivi i izraženi u ovisnosti o boji objekta i pozadine) jer gotovo uvijek postoji nekakvo osvjetljenje (prirodno ili umjetno). Prilikom snimanja scene isključivo u infracrvenom spektru vidljivi su oni objekti koji su osvjetljeni infracrvenim zrakama pri čemu registracijska pločica

zbog iznimne refleksivnosti treba biti najjače izražena. Međutim javlja se problem sunčevog infracrvenog zračenja koje može biti značajno tijekom dana, a noću ga nema. To uzrokuje veliku razliku u količini osvijetljenja na fotografijama snimljenim u različito vrijeme što dodatno otežava cijeli problem. U nastavku su prikazane dnevne fotografije snimljene u oba spektra te samo u infracrvenom spektru.




Sl. 3.2. Primjer fotografije u vidljivom i infracrvenom spektru (lijevo), fotografije u infracrvenom spektru (desno)

Zbog brže obrade ulazne fotografije, rezolucija ulaznih fotografija je postavljena na 640x480 elemenata slike. Kako se od sustava zahtijeva prepoznavanje registracijskih oznaka i u slučaju kretanja vozila malom brzinom, vrijeme ekspozicije senzora kamere mora biti što je moguće manje kako bi okvir (fotografija) bila što bistrija. Stoga je vrijeme ekspozicije (vrijeme u kojemu senzor prikuplja svjetlost) postavljeno na 50 μ s. Sustav bi za što bolje rezultate trebao biti postavljen na prosječnu visinu registracijske pločice vozila sa što je moguće manjim kutom s obzirom na vozilo, te je potrebno obratiti pažnju da se registracijska pločica nalazi otprilike nasred kadra (središta slike). Sustav se temelji na specifičnom reflektivnom materijalu od kojega je izrađena registracijska pločica u većini zemalja svijeta. Reflektivni materijali omogućuju odbijanje svjetlosti pod istim kutom pod kojim je zraka svjetlosti doputovala do površine. Uz navedenu pretpostavku moguće je pomoću infracrvenog iluminatora osvijetliti scenu pri čemu bi registracijska oznaka trebala biti znatno izraženija u odnosu na druge objekte.

3.2. Sastavljanje predloženog sustava

Sustav je sastavljen pomoću izrađenih nosača koji drže leću i kameru te nosača koje drže neeksponirani izrađeni fotografski film koji predstavlja propusni filter za infracrvenu svjetlost (engl. *IR pass filter*). Ispred leće je postavljen infracrveni iluminator. Korišten iluminator je infracrveni iluminator s 48 IR dioda [8]. Ovakav iluminator, zbog svog oblika nije idealan za osvjetljavanje registracijske pločice, ali je zbog jednostavnosti izrade odabran kao rješenje za potrebe iluminacije. S poboljšanjem iluminatora, tj. izradom iluminatora u obliku registracijske pločice (pravokutnika sa stranicama u omjeru 1:5) ostvario bi se značajan doprinos s obzirom na kvalitetu izvođenja cijelog prepoznavanja registracijske oznake. Sustav je sastavljen kako je prikazano na slici 3.3.



Sl. 3.3. Sastavljanje sustava pomoću izrađenih nosača

3.3. Prikupljanje ulaznih podataka (fotografija)

Prilikom prikupljanja ulaznih podataka za razvijanje sustava obraćena je pažnja na prikupljanje podataka u što različitijim uvjetima. Prikupljane su fotografije u različitim dobima dana kako bi se dobile fotografije sa što različitim uvjetima osvjetljenja. Također su snimane noćne fotografije kao i fotografije za vrijeme oblačnog vremena. Prilikom snimanja fotografija, sustav s kamerom je bio postavljan pod različitim kutovima i udaljenostima u odnosu na snimano vozilo. Primjeri dobivenih fotografija s predloženim sustavom su dani na slici 3.4..

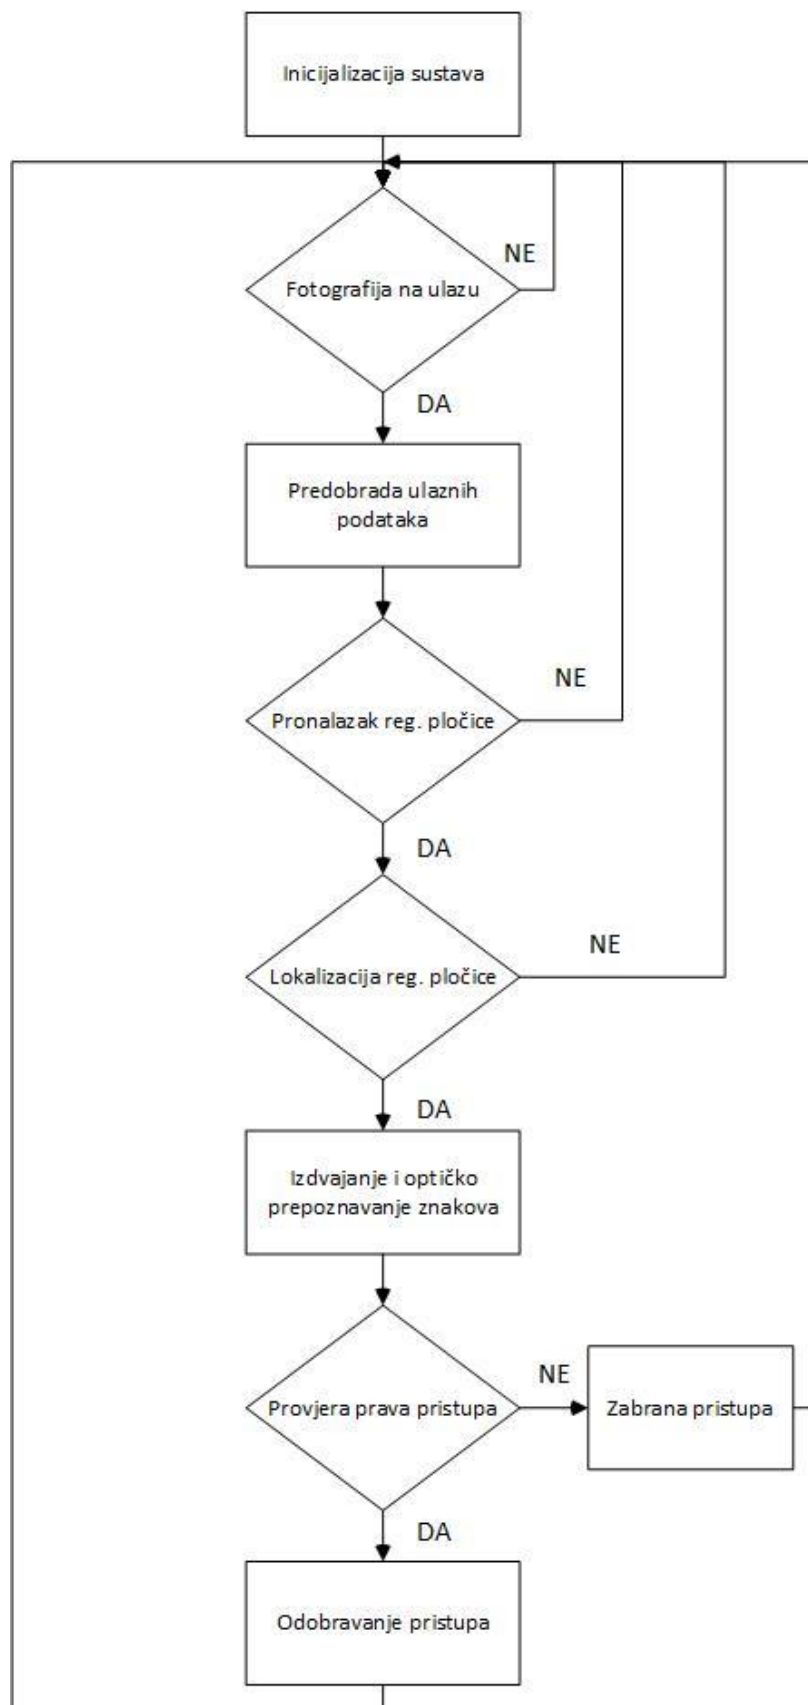


Sl. 3.4. Primjeri prikupljenih fotografija

4. PROGRAMSKO RJEŠENJE ANPR SUSTAVA

Algoritam za prepoznavanje registracijskih oznaka je razvijan u Python programskom jeziku pomoću OpenCV biblioteke. Nakon razvijanja idejnog algoritma za pronalazak i lokalizaciju registracijske pločice te izdvajanja znakova, algoritam je prebačen u C++ programski jezik. Projekt je realiziran u QT okruženju na Windows operacijskom sustavu s Tesseract 3.2 bibliotekom te Qt okruženju na Linux operacijskom s Tesseract 4.0 bibliotekom. QT je odabran jer je izrađeni programski kod lako prebaciti na platformu s drugim operacijskim sustavom (npr. Windows, Linux. i sl.). Nakon što je algoritam u potpunosti razvijen na osobnom računalu, isti je prebačen u prilagođeno Linux okruženje kako bi se mogao izvoditi na Raspberry Pi mikroračunalu.


Na slici 4.11. prikazano je programsko rješenje u obliku funkcionalnog blok dijagrama. Algoritam kao ulaz prima fotografiju na kojoj se nalazi vozilo s potpuno vidljivom registracijskom pločicom, nakon čega se izvodi predobrada ulazne fotografije koje rezultira slikom rubova objekta na fotografiji. Slika rubova se potom šalje u algoritam za pronalazak registracijske pločice koji kao rezultat vraća koordinate pravokutnika koji opisuje registracijsku pločicu. Pomoću tog pravokutnika, izdvaja se područje koje predstavlja registracijsku pločicu na posebnu sliku. Takva slika se šalje u algoritam za lokalizaciju registracijske pločice koji kao rezultat vraća četiri koordinate koje opisuju uglove registracijske pločice. Nakon toga je moguće pronaći i izdvojiti znakove te izvesti optičko prepoznavanje. Nakon poznate registracijske oznake moguće je obaviti provjeru pristupa.



Sl. 4.1. Funkcijski blok dijagram predloženog rješenja

4.1. Predobrada ulazne fotografije

Ulazna slika koja je učitana u crno-bijelim tonovima se normalizira, odnosno provodi se rastezanje kontrasta. Pri tome najsvjetliji element unutar slike dobiva vrijednost 255 a najtamniji vrijednost 0. Na taj način se povećava kontrast između interesnog područja registracijske pločice i ostatka fotografije kako bi se povećala jasnoća rubova i omogućila lakša detekcija istih. Nakon rastezanja kontrasta, izračunavaju se gradijenti svjetline u horizontalnom i vertikalnom smjeru pomoću filtriranja sa Sobel operatorom (maskom) kako bi se istaknuli oštri prijelazi na slici [9]. Na taj način je moguće izdvojiti rubove objekta na slici. Za izgrađeni sustav, empirijski je utvrđeno da Sobel maska veličine 3x3 daje dostatne rezultate za daljnju obradu slike u algoritmu za raspoznavanje registracijske oznake. Veličinu maske nije moguće pretjerano mijenjati s obzirom na relativno malu veličinu ulazne fotografije. Primjer filtriranja ulazne slike Sobelovim filtrom dan je na slici 4.2. Dobiveni gradijenti svjetline su prikazani u sivim, bijelim i crnim tonovima (bojama). Gradijenti svjetline s pozitivnom (elementi slike 4.2. prikazani bijelom bojom) ili negativnom (elementi slike 4.2. prikazani crnom bojom) vrijednošću elementa slike upućuju na prijelaze (rubove) dok vrijednosti približno jednake nuli (elementi slike 4.2. prikazani sivom bojom) predstavljaju područje koje nije od interesa.



Sl. 4.2. Gradijenti svjetline u vertikalnom i horizontalnom smjeru


Gradijenti svjetline ovisno o svojoj vrijednosti upućuju na oštrinu (jačinu) prijelaza (ruba), tako je moguće razlikovati nagle i blage prijelaze koji su na slici 4.2. prikazani različitim kontrastima bijele i crne boje. Sliku koja sadrži gradijente svjetline potrebno je binarizirati kako bi se dobila slika koja predstavlja rubove objekta jednom bojom (npr. 255) a ostalo područje nekom drugom (npr. 0). Binarizacija se provodi metodom praga tako da se gradijenti svjetline skaliraju u interval $\{0,10\}$ te se uzima prvih i posljednjih 40% vrijednosti, dok se ostalih 20% vrijednosti

smatra pozadinom odnosno područjem koje nije od interesa. Primjer funkcije odluke za takvo binariziranje je dan u nastavku.



Sl. 4.3. Primjer funkcije odluke kod postupka binariziranja slike gradijenata svjetline

Kao rezultat se dobivaju slike na kojima su jasno istaknuti vertikalni odnosno horizontalni rubovi objekta (Sl.4.4).

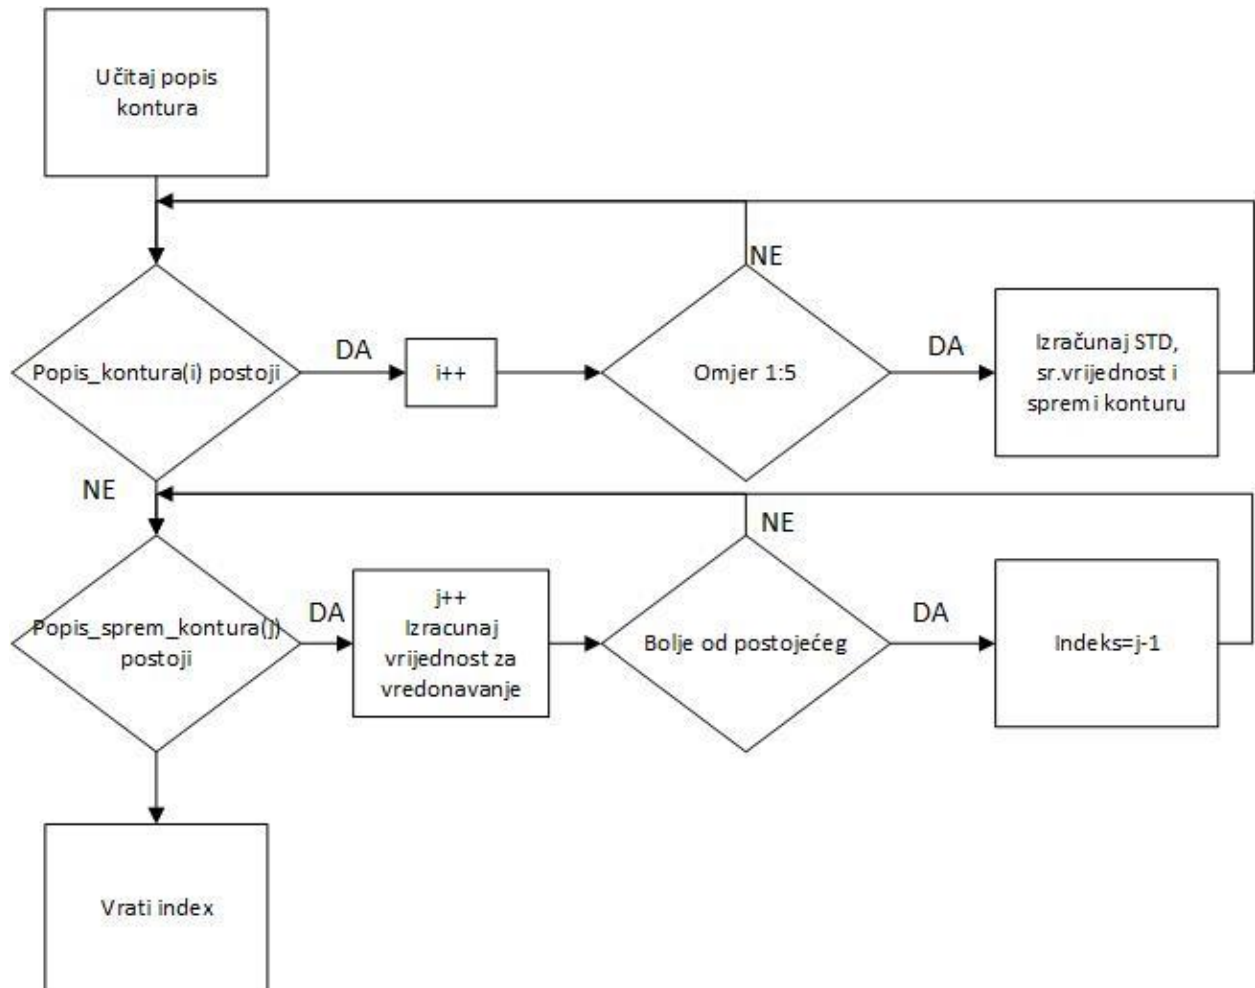


Sl. 4.4. Primjeri binarnih slika vertikalnih i horizontalnih gradijenata svjetline

Zbrajanjem vrijednosti binarnih slika vertikalnih i horizontalnih gradijenata svjetline (Sl.4.4.) pomoću logičkog I operatora za matrice, moguće je dobiti sliku koja predstavlja pronađene rubove na ulaznoj fotografiji. Takva binarna slika je ulaz u idući korak algoritma za prepoznavanje registracijske oznake.

4.2. Pronalaženje kandidata registracijske pločice

Na slici 4.5. dan je funkcijski blok dijagram za pronalaženje najboljeg kandidata registracijske oznake.



Sl. 4.5. Funkcijski blok dijagram algoritma za pronalazak kandidata registracijske pločice

Slika rubova se šalje u algoritam *findContours()* dostupan u OpenCV biblioteci [10]. Algoritam kao rezultat vraća dvije strukture podataka, jedna sadrži sve pronađene konture opisane pomoću točaka, te druga koja sadrži hijerarhijske odnose između kontura koje se u nastavku ne razmatraju. Kontura je niz elemenata slike m_1, m_2, \dots, m_n takav da svaki element niza pripada N^s susjedstvu prethodnog elementa [9], tj. svaki promatrani element slike je povezan s njemu dva susjedna elementa odnosno ti elementi imaju iste vrijednosti. N^s susjedstvo predstavlja osam elemenata slike koji se nalaze okolo promatranog elementa odnosno dodiruju taj element. Kada je prvi element takvog niza jednak posljednjem onda se radi o zatvorenoj konturi.

Za svaku dobivenu konturu moguće je pomoću OpenCV ugrađenih funkcija dobiti pravokutnik koji apsolutno obuhvaća konturu, tj. pravokutnik opisan pomoću 4 parametra: x i y koordinata lijevog gornjeg ugla, te visine i širine. Također pomoću ugrađene funkcije moguće je dobiti pravokutnik koji opisuje konturu (područje) s minimalnom površinom odstupanja te je opisan pomoću 5 parametara, x i y koordinatom središta, visinom i širinom te kutom zakrenutosti pravokutnika. Na slici 4.6. (lijevo) moguće je vidjeti dobivenu binarnu sliku rubova iz prethodnog koraka koja se šalje u algoritam za pronalaženje kandidata registracijske pločice, te rezultat izvođenja algoritma za detekciju kandidata registracijske pločice.



Sl. 4.6. Primjer slike rubova koja se obrađuje algoritmom za pronalazak reg. pločice (lijevo) i primjer pronađenih kontura koje opisuju registracijsku pločicu (desno)

Prolaženjem kroz strukturu svih kontura pronalaze se kandidati za tablicu koji odgovaraju omjeru tablice te se tako formira popis mogućih kandidata. Za svakog kandidata se izračunava srednja vrijednost i standardna devijacija za sliku opisanu konturom s minimalnom površinom odstupanja. Ideja je na temelju srednje vrijednosti i standardne devijacije „nagrađivati“ moguće kandidate za registracijsku pločicu. Naime registracijska pločica je uglavnom bijela što će rezultirati relativno velikom srednjom vrijednošću, a postoje i elementi slike koji su potpuno crni (znakovi na tablici), stoga će i vrijednost standardne devijacije biti relativno velika.

Nakon generiranja popisa mogućih kandidata koji odgovaraju omjeru registracijske pločice s pripadajućim srednjim vrijednostima i standardnim devijacijama, za svakog kandidata se pomoću slike vertikalnih rubova izračunava broj elemenata koji predstavljaju rubove s obzirom na površinu kandidata. Na slici 4.7. prikazane su fotografije kandidata s pripadnim binarnim slikama vertikalnih rubova.



Sl. 4.7. Primjer kandidata za tablicu i njihove vrijednosti vertikalnih rubova

Ideja je na temelju broja rubova s obzirom na površinu i činjenice da se na tablici nalaze znakovi koji moraju imati izražene vertikalne rubove „nagrađivati“ moguće kandidate u ovisnosti o spomenutom uvjetu. Vidljivo na slici 4.7. najveći broj elementa koji predstavljaju rubove nalazi se na posljednjem primjeru.


Na temelju tog uvjeta, spomenute srednje vrijednosti i standardne devijacije izračunava se vrijednost za vrednovanje kandidata. Kao dodatna vrijednost se koristi duljina dijagonale kandidata kako bi bio odabran najveći kandidat koji opisuje registracijsku pločicu. Duljina dijagonale se koristi jer se može dogoditi parcijalan pronalazak registracijske pločice. Parcijalan pronalazak se događa kada algoritam pronalazi rub na nekom od znakova zapisanih na registracijskoj pločici. Nakon izvršavanja algoritma dobiva se najvjerojatniji kandidat opisan pomoću pravokutnika, tj. x i y koordinate lijevog gornjeg ugla te visine i širine.

4.3. Lokalizacija registracijske pločice

Nakon dobivanja najvjerojatnijeg kandidata za isti se pokušavaju odrediti 4 pravca koji opisuju položaj registracijske pločice na slici kako bi se provela što točnija lokalizacija same pločice. Pravci se određuju pomoću OpenCV funkcije *HoughLines()* [11] koja kao parametar prima sliku rubova objekta te broj glasova koji pravac mora sadržavati kako bi se smatrao pravcem. Funkcija kao rezultat vraća popis pravaca opisanih pomoću dva parametra, kuta zakrenutosti i udaljenosti od ishodišta [12]. Tada se jednadžba pravca može opisati pomoću izraza:

$$r = x * \cos(\theta) + y * \sin(\theta) \quad (3 - 1)$$

Primjer takve parametrizacije je moguće vidjeti na slici 4.8., gdje je r udaljenost, a θ kut zakrenutosti u odnosu na ishodište.



Sl. 4.8. Primjer parametrizacije pravca pomoću kuta i udaljenosti

Kako bi se pravci što točnije detektirali umjesto prosljeđivanja slike ukupnih rubova algoritmu za lokalizaciju registracijske pločice se prosljeđuje binarna slika vertikalnih ili horizontalnih rubova ovisno koji se rubovi žele detektirati. Horizontalni pravci se određuju na način da se na temelju slike horizontalnih rubova pronalazi par pravaca koji zadovoljava uvjete glasovanja, zatim uvjete da su promatrana dva pravca približno paralelna te da im udaljenost od ishodišta u velikoj mjeri nije jednaka. Udaljenost od ishodišta uvedena je kao uvjet kako bi se izbjeglo uzimanje u obzir pravaca koji opisuju isti rub registracijske pločice s različitim, a opet vrlo sličnim parametrima.

Za pronalaženje parova pravaca koji opisuju vertikalne rubove nije moguće poslati sliku vertikalnih rubova jer postoje rubovi znakova koji često znaju biti izraženiji (sadržavaju veći broj elemenata slike) od samoga ruba registracijske pločice kao što je prikazano na slici 4.9.. Za što točniju lokalizaciju potrebno je ulaznu sliku filtrirati odnosno ukloniti sve rubove osim rubova registracijske pločice. Filtriranje se izvodi tako da se na slici vertikalnih rubova ostavljaju samo najljeviji i najdesniji elementi slike što rezultira slikom s vanjskim rubovima debljine jedan element. Slike s debljinama rubova jedan element predstavljaju najbolje slike za pronalaženje linija pomoću Houghove transformacije s obzirom da se ne mogu dogoditi opisivanja istih rubova različitim parametrima (npr. iznimno mala promjena kuta zakrenutosti). Na slici 4.9. moguće je vidjeti rezultat ovakvog filtriranja u svrhu pojednostavljivanja vertikalnih rubova za lakšu lokalizaciju pravaca koji opisuju registracijsku pločicu.



Sl. 4.9. Primjer slike rubova prije (lijevo) i nakon čišćenja (desno)

Tako dobivena slika se šalje u *HoughLines()* algoritam te se na temelju spomenutih uvjeta pronalazi par pravaca koji opisuje vertikalne rubove registracijske pločice. Na temelju pronađena četiri pravca izračunavaju se četiri točke sjecišta pravaca koje opisuju koordinate uglova registracijske pločice. Sjecište dvaju pravaca predstavlja rješenje sustava jednadžbi ta dva pravca koja se mogu dobiti matričnim računom. Naime na temelju izraza (3-1) pravce je moguće zapisati u obliku matrica (izraz (3-3)) kako je prikazano u nastavku pri čemu vrijedi izraz (3-2):

$$A * x = B \quad (3 - 2)$$

$$A = \begin{bmatrix} \cos(\theta_1) & \sin(\theta_1) \\ \cos(\theta_2) & \sin(\theta_2) \end{bmatrix}, B = \begin{bmatrix} r_1 \\ r_2 \end{bmatrix}, x = \begin{bmatrix} x \\ y \end{bmatrix} \quad (3 - 3)$$

Izraz (3-2) se može zapisati kao:

$$A^{-1} * A * x = A^{-1} * B \quad (3 - 4)$$

Iz čega slijedi:

$$I * x = A^{-1} * B \quad (3 - 5)$$

Odnosno:

$$x = A^{-1} * B \quad (3 - 6)$$

Pri čemu vrijedi:

$$A^{-1} = \frac{1}{\det(A)} * adj(A) \quad (3 - 7)$$

Rješavanjem izraza (3-6) za odgovarajuće pravce (pravce koji se sijeku) dobivaju se koordinate sjecišta pravaca.



Sl. 4.10. Primjer pravaca koji opisuju registracijsku pločicu

Na temelju četiri točke koje opisuju registracijsku pločicu na fotografiji (nepravilni četverokut) i četiri točke kako bi tablica trebala izgledati (pravokutnik s omjerom stranica 5:1) ugrađenim OpenCV algoritmom moguće je izračunati matricu homografije. Matrica homografije je matrica od devet elemenata koji sadrže podatke o položaju objekta (u ovome slučaju registracijske pločice) u odnosu na položaj tog objekta na fotografiji snimljenoj pod drugim kutom. Naime matrica homografije sadrži podatke o promjeni položaja kamere (rotacija i translacija) u odnosu na ispravno spareni par točaka na obje fotografije. Nakon izračunavanja, pomoću matrice homografije moguće je dobiti ispravljenu perspektivu fotografije ako su četverokuti koji opisuju objekt u referentnom i radnom stanju ispravno definirani. Matricu homografije je moguće izračunati na temelju 4 točke metodom izravne linearne transformacije (engl. *Direct Linear Transform DLT*) ili nekom drugom metodom predstavljenom u [13]. Nakon dobivanja ispravljene slike pomoću matrice homografije izdvaja se područje od interesa koje ustvari predstavlja registracijsku pločicu. Na slici 4.11. prikazana je ispravljena slika 4.10. uz upotrebu odgovarajuće matrice homografije.



Sl. 4.11. Primjer fotografije nakon ispravljanja perspektive pomoću matrice homografije


4.4. Pronalaženje znakova na tablici

Kako bi se moglo provesti optičko prepoznavanje znakova na registracijskoj pločici, potrebno je lokaliziranu sliku registracijske pločice razdvojiti na niz slika pri čemu svaka slika sadržava jedan znak. Kako bi se pronašli mogući znakovi, lokalizirana slika registracijske pločice se binarizira. Dobivena slika registracijske pločice se binarizira adaptivnim algoritmom binariziranja (engl. *adaptive thresholding*) koji za razliku od globalnog binariziranja promatra sliku kroz prozore definirane veličine. Ovakav pristup je prikladniji zbog izražene neujednačenosti osvjetljenja registracijske pločice iluminatorom. Također postoje razlike u prirodnom osvjetljenju kao i razlike zaprljanosti registracijske oznake. Stoga se kao najbolje rješenje pokazalo korištenje adaptivnog algoritma za binariziranje. Nakon binariziranja lokalizirane slike registracijske pločice, moguće je pomoću odgovarajućeg algoritma pronaći znakove na tablici. Pronalaženje znakova na tablici se zasniva na pronalasku kontura na binarnoj slici registracijske pločice. Prije samog prosljeđivanja binarne slike lokalizirane registracijske pločice u algoritam za pronalaženje kontura, izvode se morfološke operacije dilatacije i erozije u svrhu čišćenja nečistoća i sitnih oštećenja registracijskih pločica. Na slici 4.12. je prikazan rezultat takvog čišćenja.



Sl. 4.12. Slika binariziranih registracijski pločica prije i nakon čišćenja pomoću morfoloških operacija

Također prije slanja u algoritam za pronalazak kontura na tablici, slici se proširuju rubovi kako bi svi znakovi bili odvojeni od ruba slike. Dobivena binarna slika se šalje u spomenuti algoritam *findContours()* koji vraća popis pronađenih kontura odnosno kandidata znakova. Kandidati se filtriraju s obzirom na visinu znaka. Visina znaka treba biti nešto manja nego što je visina registracijske oznake.




Sl. 4.13. Primjer pronađenih kontura

Na slici 4.13. prikazan je rezultat primjene algoritma za pronalazak kontura koje opisuju znakove. Može se uočiti da znakovi poput slova o, d ili znamenke nula mogu sadržavati konturu koja opisuje unutarnje rubove promatranog znaka. Takve konture moguće je odbaciti nakon sortiranja kontura s obzirom na x koordinatu kako bi se dobili međusobni odnosi kontura odnosno položaj promatrane konture u odnosu na ostale. Tada je moguće na temelju izračunavanja udaljenosti između susjednih kontura zaključiti da se jedna kontura nalazi unutar druge i kao takvu ju odbaciti iz popisa kontura. Kao izlaz se dobiva popis koordinata pravokutnika kandidata koji predstavljaju znakove.

4.5. Prepoznavanje znakova

Algoritam za prepoznavanje znakova u ovome radu se koristi Tesseract bibliotekom namijenjenom za optičko prepoznavanje znakova. Biblioteka je u najvećoj mjeri kreirana za prepoznavanje i čitanje skeniranih ili fotografiranih stranica tekstualnog zapisa, a može prepoznavati i pojedine znakove. Biblioteka se bazira na prilagođenom podudaranju susjedstva elementa slike (engl. *Template matching*) i korištenju rječnika. Kako metoda podudaranja susjedstva elementa slike zahtijeva definirane uzorke koje može prepoznavati tako i Tesseract zahtijeva skup treniranih podataka za određeni jezik. Trenirani podaci sadržavaju uzorke određenih znakova kao i spomenute rječnike. Kako se najčešće optički prepoznaju čitave riječi, korištenjem rječnika je moguće semantički provjeriti dobiveni tekst koji je generirao algoritam te ponuditi najbližnju riječ iz rječnika. Rječnici sadržavaju riječi koje se najčešće upotrebljavaju u promatranom jeziku. Tesseract omogućava prepoznavanje 100 različitih jezika s nekoliko različitih treniranih podataka. Na primjer, postoje setovi podataka namijenjeni za što brže izvođenje i setovi podataka namijenjeni za što točnije optičko prepoznavanje. U ovome radu su korišteni uobičajeni trening podaci koji dolaze prilikom instalacije biblioteke. Najnovija inačica biblioteke Tesseract omogućava prepoznavanje temeljeno na neuronskim mrežama i drugim pametnim algoritmima. U radu je korištena C++ verzija biblioteke Tesseract Baseapi koja omogućuje kreiranje Tesseract objekta i postavljanje raznih parametara kao što su jezik teksta za prepoznavanje, način segmentacije ulazne slike, znakovi koji se žele prepoznavati i druge opcije. Tesseract sam u sebi ima ugrađene algoritme za ispravljanje orijentacije teksta i binariziranje ulazne fotografije no za što bolje rezultate potrebno je samostalno prethodno pripremiti ulaznu fotografiju. Kao priprema smatra se postavljanje odgovarajuće rezolucije, uklanjanje rotacije, rubova i slično. U ovome radu su testirane inačice biblioteke 3.2 i 4.0 pri čemu verzija 4.0 ostvaruje znatno bolje rezultate.

Prije samog optičkog prepoznavanja potrebno je izolirati sliku pojedinačnog simbola kako bi se provela što točnija binarizacija. Naime prvi i posljednji znak na fotografiji registracijske pločice nisu jednako iluminirani i stoga nije moguće ispravno binarizirati fotografiju znakova ako se binarizacija provodi na ukupnoj slici znakova. U nastavku su prikazane razlike u osvjetljenju na početnom i krajnjem znaku na dvije različite registracijske pločice.



Sl. 4.14. Primjer u različitosti osvjetljenja početnog i krajnjeg znaka na registracijskoj pločici

Nakon binariziranja pojedinačnog znaka, provode se spomenute morfološke operacije erozije i dilatacije na pojedinačnom znaku. Također se provodi implementirani algoritam za uklanjanje moguće rotacije znaka. Slike pojedinih binariziranih znakova se uvećavaju 2 puta te se lijepe na veću sliku s jednakim udaljenostima između svakoga znaka kako je vidljivo u nastavku.



Sl. 4.15. Primjer slike za slanje u Tesseract algoritam

Takva slika se šalje u Tesseract algoritam na optičko prepoznavanje. Tesseract biblioteka Baseapi omogućava kreiranje Tesseract *iteratora* na temelju riječi ili znakova. U ovome radu je korišten *iterator* za pojedine znakove. *Iterator* za svaki pojedini znak vraća najvjerojatniji znak s pripadnom mjerom sigurnosti kao i popis ostalih mogućih znakova s odgovarajućim sigurnostima. U ovome radu je empirijski određeno kada prepoznati znak ima mjeru sigurnosti manju od 75%, tada se znak smatra krivo prepoznatim. Na temelju vraćenih rezultata kreira se popis koji za svaki znak s registracijske oznake sadrži najvjerojatnije slovo kao i najvjerojatniju znamenku. Također se kreira popis s pripadnim sigurnostima za svako slovo odnosno znamenku.

S poznatim popisom koordinata pravokutnika koji opisuju znakove i na temelju informacije o udaljenosti između pojedinih znakova moguće je podijeliti znakove na klase temeljem najvećih razmaka koji se nalaze između znakova. Tako se npr. za registracijsku oznaku sa slike 4.16 dobiva da prva dva znaka pripadaju klasi 1, sljedeća tri znaka klasi 2 te sljedeća dva znaka klasi 3 kako je prikazano u nastavku.

VU 808 DN

Sl. 4.16. Znakovi odvojeni na klase na temelju međusobne udaljenosti

Naravno postoje samo dvije klase a to su znamenke i slova. Ovaj pristup je primijenjen jer u RH registracijske oznake koriste isti simbol za slovo O i znamenku 0 pri čemu format registracijske oznake definira samo da prva dva znaka moraju biti slova koja označavaju mjesto pod kojim je vozilo registrirano dok ostali znakovi mogu biti slova ili brojevi. Na taj način je otežano prepoznavanje registracijske oznake i potrebno je dodatno razlučivanje na temelju odgovarajućih pravila. Kako na području RH nisu definirana striktna pravila koja bi mogla određivati radi li se o znamenki ili slovu, predloženi algoritam sam raspoznaje radi li se o znamenki ili slovu na temelju klasa njegovih susjednih znakova. Na taj način je omogućeno prepoznavanje i neuobičajenih registracijskih pločica od kojih su neke prikazane u nastavku.



Sl. 4.17. Primjer različitih formata registracijske oznake u RH

Na temelju popisa pripadajućih sigurnosti i klasa dodijeljenih svakome znaku provodi se provjera pripadnosti pojedine klase. Naime na registracijskim oznakama RH prva klasa odnosno prva dva znaka moraju biti slova dok ostale klase mogu biti slova ili znamenke. Daljnji postupak se stoga ne provodi za prvu klasu. Za svaku preostalu klasu se računa ukupna pripadnost znamenkama i slovima na temelju vraćenih mjera sigurnosti za određeno slovo odnosno znamenku. Tako se na primjer za sliku 4.15 dobiva da znakovi (7,9,7) iz klase 2 pripadaju brojevima s mjerom 90% dok je mjera pripadanja za slova jednaka 50%. Izborom veće vrijednosti algoritam sam prepoznaje o kojoj se klasi znakova radi.

Nakon dobivanja podataka o pripadnosti pojedinog znaka klasama, moguće je izabrati najbolja ponuđena rješenja za svaki znak u ovisnosti o pripadajućoj klasi. Tako se npr. za sliku dobiva da klasa 2 predstavlja znamenke dok klasa 3 predstavlja slova. Nakon izbora najboljih rješenja za pojedini znak provodi se dodatna provjera za simbole D, O i U koji najčešće zbog velike

sličnosti mogu biti krivo prepoznati. Provjera se provodi kada je detektirani znak neki od spomenutih na način da se uzima u obzir mjera sigurnosti koja je vraćena za simbol 0. Ako je mjera sigurnosti za simbol 0 vrlo slična ili veća od mjere sigurnosti za ponuđeno slovo, može se zaključiti da se zapravo radi o slovu O. Algoritam kao rezultat vraća tekst zapisan na ulaznoj slici.

4.6. Provjera prava pristupa i administracija ANPR sustava

Nakon uspješnog lokaliziranja registracijske pločice i prepoznavanja registracijske oznake istu je potrebno provjeriti sa svim korisnicima sustava. Korisnici sustava uobičajeno su spremljeni u bazi podataka koja može biti smještena lokalno na računalu ili najčešće na udaljenom serveru. Razlog smještanja na udaljeni server je mogućnost pristupa s više različitih uređaja putem internetske veze.

U ovome radu je korištena SQLite baza podataka namijenjena za manje korisnike odnosno korisnike s manjim brojem zapisa. SQLite bazom podataka se upravlja pomoću klasičnih SQL upita. SQLite bazu podataka nakon kreiranja, moguće je povezati s QT okruženjem s ugrađenim funkcijama. Tada se upiti pišu u obliku *stringova* koji se šalju ugrađenim funkcijama. U radu je kreirana i korištena jedna baza podataka s dvije tablice, tablicom korisnika i tablicom pristupa. U radu je implementirana sva nužna podrška za administraciju korisnika u bazi podataka odnosno podrška za pregled postojećih i dodavanja novih korisnika te promjenu prava pristupa kao i pregled svih provjera koje su obavljene predloženim sustavom za prepoznavanje registracijskih oznaka. Administracija je omogućena isključivo administratoru sustava koji se mora identificirati pomoću korisničkog imena i zaporke u previđenom djelu korisničkog sučelja. Administrator može dodavati nove korisnike s ograničenjima da jedna registracijska oznaka u bazi podataka može imati samo jednog vlasnika dok jedan vlasnik može imati više različitih registracijskih pločica zapisanih u bazi podataka. Svakom se korisniku nakon uspješne identifikacije ovisno o razini prava omogućava ili zabranjuje prilaz. Prilikom pretrage baze podataka za određenu registracijsku oznaku pretražuju se samo one registracijske oznake koje odgovaraju mjestu u kojem je pretraživano vozilo registrirano kako bi se vrijeme izvođenja u što većoj mjeri smanjilo. Izgled korisničkog i administracijskog sučelja je moguće vidjeti u prilogu.

5. REZULTATI

Nakon razvijanja algoritma za prepoznavanje registracijskih oznaka, predloženi sustav je testiran na dva različita operacijska sustava. Sustav je testiran na Linux Ubuntu operacijskom sustavu instaliranom u virtualnom stroju na osobnom računalu uz korištenje Tesseract 4.0 biblioteke. Sustav je također testiran na Linux baziranom operacijskom sustavu Raspbian na Raspberry Pi 3B mikroračunalu uz korištenje Tesseract 4.0 biblioteke. Izgled korisničkog sučelja moguće je vidjeti u prilogu.

U testiranju predloženog sustava nisu se uzimale u obzir fotografije koje ne zadovoljavaju početno postavljena ograničenja. Dva takva primjera su prikazana u nastavku.



Sl. 5.1. Primjeri fotografija neuspješnih prepoznavanja ili lokaliziranja

Desna fotografija na slici 5.1 prikazuje situaciju kada registracijska pločica sadrži nedovoljan broj elemenata slike zbog prevelike udaljenosti od kamere sustava. Lijeva fotografija na slici 5.1 prikazuje situaciju kada registracijska pločica nije ni približno u sredini kadra pa nije direktno iluminirana čime nisu jasno naznačena promatrana svojstva registracijske pločice. Također se nisu uzimale u obzir fotografije snimljene pod prevelikim kutom. Problem takvih fotografija je omjer visine i širine registracijske pločice na fotografiji. Naime takve fotografije imaju omjer ispod postavljenog kriterija u ovome radu pa se na takvim fotografijama algoritam zaustavlja prije lokaliziranja registracijske pločice.

Pri prikupljanu fotografija, prikupljeno je 106 fotografija 13 različitih registracijskih oznaka. Pri razvijanju sustava korišteno je 70 fotografija, dok je preostalih 36 fotografija korišteno isključivo pri testiranju.

Od 70 prikupljenih fotografija na kojima je ovaj sustav razvijan, točno prepoznavanje registracijske oznake odnosno identificiranje je ostvareno na svih 70 fotografija. Na testiranih 36 fotografija, registracijska pločica je uspješno prepoznata i lokalizirana na 35 fotografija (jedna fotografija je snimljena pod prevelikim kutom pa algoritam ne pronalazi kandidata za registracijsku pločicu). Od preostalih 35 fotografija registracijski pločica, točno prepoznavanje registracijske oznake je ostvareno na 34 fotografije. To bi značilo da implementirani sustav ima točnost 99%.


Kako bi se sustav dodatno testirao u smislu optičkog prepoznavanja, na internetu je pronađeno dodatnih 40 fotografija s različitim registracijskim oznakama. Bitno je naglasiti da pronađene fotografije nisu nužno jednakih dimenzija kao i snimljene fotografije. Tako postoje fotografije većih i manjih dimenzija u odnosu na pretpostavljene. Također bitna razlika je što su te fotografije snimane u vidljivom spektru svjetlosti što utječe na samo izvođenje cijelog algoritma. Naime predloženi sustav je razvijan na temelju fotografija u infracrvenom spektru svjetlosti. Na uzorku od 40 fotografija točno je prepoznato svih 40 registracijskih oznaka. To se može protumačiti na način da snimanje u isključivo infracrvenom spektru svjetlosti uvodi šum na snimljenu fotografiju. Odnosno takva fotografija sadrži puno manje detalja, tj. korisne informacije za ovaj specifični slučaj u odnosu na fotografiju snimljenu u vidljivom spektru.

Sustav je testiran na dvije računalne platforme kako bi se vidjelo vrijeme izvođenja na nekoj ugradbenoj računalnoj platformi (engl. *embedded system*) na kojoj bi se ovakav algoritam mogao izvršavati u praksi. Kako je sustav testiran na dvije različite platforme, u nastavku je dana tablica s vremenima izvođenja za pojedine dijelove algoritma.

Tablica 5.1 Prosječna vremena izvođenja pojedinih algoritama u milisekundama

Linux Ubuntu Virtualni stroj	Minimalno vrijeme izvođenja	Maksimalno vrijeme izvođenja	Medijan vremena izvođenja	Srednja vrijednost vremena izvođenja	Standardna devijacija	Postotak standardne devijacije
Raspberry Pi 3B						
Predobrada i pronalazak tablice	0	4	1	1.511	0.788	52.15
	7	26	12	12.91	4.169	32.29
Lokalizacija tablice	11	20	13	13.38	1.7664	13.20
	89	163	109	110.27	7.389	6.70
Izvođenje Tesseract algoritma	120	177	127	132.3372	11.2752	8.52
	1140	1292	1176	1182.96	22.52	1.90
Izvođenje potpunog optičkog prepoznavanja	122	178	129	133.65	11.3432	8.48
	1152	1302	1187	1191.92	22.7	1.90
Izvođenje potpunog algoritma	136	212	145	150.569	13.813	9.17
	1278	1419	1316	1321.71	22.87	1.73


Prema tablici 5.1 srednje vrijeme izvođenja cijelog algoritma u virtualnom stroju s Linux operacijskim sustavom iznosi oko 150 ms, dok je srednje vrijeme izvođenja na Raspberry Pi platformi 1320 ms što je znatno sporije (devet puta) u odnosu na izvođenje na klasičnom računalu u virtualnom stroju. Promatrajući podatke pojedinih algoritma moguće je primijetiti kako algoritam za predobradu i pronalazak registracijske pločice ima najveće odstupanje. To je iz razloga što postoje fotografije s manje i više kandidata što utječe na veličinu prostora za pretraživanje a samim time i na brzinu izvođenja. Iz danih rezultata vidljivo je da ostali algoritmi nemaju izraženu standardnu devijaciju u tolikoj mjeri.




Sl. 5.2. Usporedba prosječnih vremena izvođenja pojedinog algoritma na različitim platformama

Vidljivo prema tablici 5.1 i slici 5.2, najveći udio u vremenu izvođenja cijelog algoritma na obje platforme, ima izvođenje optičkog prepoznavanja znakova pomoću Tesseract biblioteke. Kako bi se ostvarilo još brže izvođenje cijelog algoritma na jednostavnijoj platformi poput Raspberry Pi mikroračunala, potrebno je implementirati jednostavniju i bržu metodu optičkog prepoznavanja.


U nastavku je prikazana usporedba histograma vremena izvođenja pojedinih algoritama na obje platforme.





Sl. 5.3. Usporedba vremena izvođenja algoritma za pronalazak reg. pločice





Sl. 5.4. Usporedba vremena izvođenja algoritma za lokalizaciju reg. pločice



Sl. 5.5. Usporedba vremena izvođenja Tesseract algoritma



Sl. 5.6. Usporedba vremena izvođenja algoritma za potpuno prepoznavanje reg. oznake



Sl. 5.7. Usporedba vremena izvođenja potpunog algoritma

Vidljivo prema prikazanim slikama svi histogrami imaju relativno usku funkciju razdiobe što govori da se vrijeme izvođenja pojedinog algoritma ne mijenja u velikoj mjeri.

6. ZAKLJUČAK

U radu je predložen sustav za prepoznavanje registracijskih oznaka pomoću računalnog vida u svrhu identifikacije vozila na temelju jedinstvene registracijske oznake.

Sustav se sastoji od Raspberry Pi mikroračunala, Raspberry Pi NOIR kamere i pripadne programske podrške. Sustav je implementiran pomoću OpenCV biblioteke i C++ programskog jezika u QT okruženju.

Programska podrška se sastoji od niza algoritama koji se slijedno izvode u svrhu prepoznavanja registracijske oznake i identifikacije korisnika sustavu. Algoritmi za prepoznavanje registracijske oznake su: algoritam za predobradu ulazne fotografije, algoritam za pronalaženje i lokalizaciju registracijske pločice, algoritam za pronalazak znakova na registracijskoj pločici, algoritam za izdvajanje i optičko prepoznavanje znakova.

U radu su ostvareni jako dobri rezultati s obzirom na točnost prepoznavanja, ali uzimajući u obzir ograničenja koja su predstavljena u radu. Predstavljeni su rezultati izvođenja na dvije različite platforme. Prosječno vrijeme izvođenja na osobnom računalu iznosi 130 ms, dok na Raspberry Pi platformi iznosi 1300 ms.

Poboljšanja su ostvariva u vidu razvijanja pametnog algoritma za prepoznavanje registracijske pločice na temelju HOG ili nekakvih drugih ekstrahiranih značajki. U smislu pametnog algoritma misli se na neku od metoda strojnog učenja. Također su moguća poboljšanja u vidu brzine izvođenja optičkog prepoznavanja znakova. Naime moguć je razvoj ili korištenje nekog drugog sustava za optičko prepoznavanje znakova koji ima brže vrijeme izvođenja.

LITERATURA

- [1] »ANPRSystems,« [Mrežno]. Available: https://en.wikipedia.org/wiki/Automatic_number_plate_recognition. [Pokušaj pristupa 10. 11. 2017.].
- [2] »Tesseract OCR,« Tesseract, [Mrežno]. Available: <https://github.com/tesseract-ocr>. [Pokušaj pristupa 10. 7. 2017.].
- [3] »Open ALPR,« [Mrežno]. Available: <http://www.openalpr.com/>. [Pokušaj pristupa 20. 6. 2017.].
- [4] »ARHungary,« [Mrežno]. Available: <http://www.arhungary.hu/index.html>. [Pokušaj pristupa 10. 11. 2017.].
- [5] »DahuaTech,« [Mrežno]. Available: http://www.dahuasecurity.com/solution_news-191-271.html. [Pokušaj pristupa 10. 11. 2017.].
- [6] »TitanHZ,« [Mrežno]. Available: <http://www.titanhz.com/automatic-number-plate-recognition-system.aspx>. [Pokušaj pristupa 10. 11. 2017.].
- [7] »Narodne Novine,« [Mrežno]. Available: https://narodne-novine.nn.hr/clanci/sluzbeni/2005_01_5_65.html. [Pokušaj pristupa 1. 8. 2017.].
- [8] »IR-Infrared-Illuminator-For-CCTV,« [Mrežno]. Available: <https://www.ebay.com/itm/48-LED-IR-Infrared-Illuminator-60-Degree-Bulb-Board-For-CCTV-Security-Camera/121800664334?epid=1284543293&hash=item1c5be2a50e:g:j00AAOSw9mFWMe6H>. [Pokušaj pristupa 10. 5. 2017.].
- [9] R. Cupec, »Temeljne operacije filtriranja,« u *Predavanja*, 2016..
- [10] »OpenCV Contours,« [Mrežno]. Available:
] https://docs.opencv.org/structural_analysis_and_shape_descriptors.html. [Pokušaj pristupa 12. 7. 2017.].
- [11] »HoughLines,« OpenCV, [Mrežno]. Available:
] https://docs.opencv.org/hough_lines/hough_lines.html. [Pokušaj pristupa 5. 7. 2017.].

- [12 »Hough transform,« [Mrežno]. Available: https://en.wikipedia.org/wiki/Hough_transform.
] [Pokušaj pristupa 5. 7. 2017.].
- [13 R. Cupec, »Raspoznavanje 3D objekata,« u *Predavanja*, 2016.
]

SAŽETAK

Rad se bavi izradom ANPR sustava za automatsku identifikaciju vozila na temelju jedinstvene registracijske oznake. U radu je dano rješenje zasnovano na računalnom vidu. Sustav se sastoji od Raspberry Pi 3B mikroračunala, Raspberry Pi NOIR kamere, te programske podrške napisane u C++ programskom jeziku i implementirane u QT okruženju pomoću OpenCV biblioteke. Implementirano programsko rješenje je predstavljeno kao niz algoritama koji se slijedno izvode. Algoritmi za prepoznavanje registracijske oznake su: algoritam za predobradu ulazne fotografije, algoritam za pronalaženje i lokalizaciju registracijske pločice, algoritam za pronalazak znakova na registracijskoj pločici, algoritam za izdvajanje i optičko prepoznavanje znakova. U radu se koristi Tesseract biblioteka kao sustav za optičko prepoznavanje znakova. Na posljetku se izvodi provjera prava pristupa korisnika. Predstavljeno je potpuno rješenje s SQLite bazom podataka. Prikazani sustav ima točnost od 99%.

Ključne riječi: ANPR, LPR, računalni vid, OpenCV, optičko prepoznavanje znakova, Tesseract

ABSTRACT

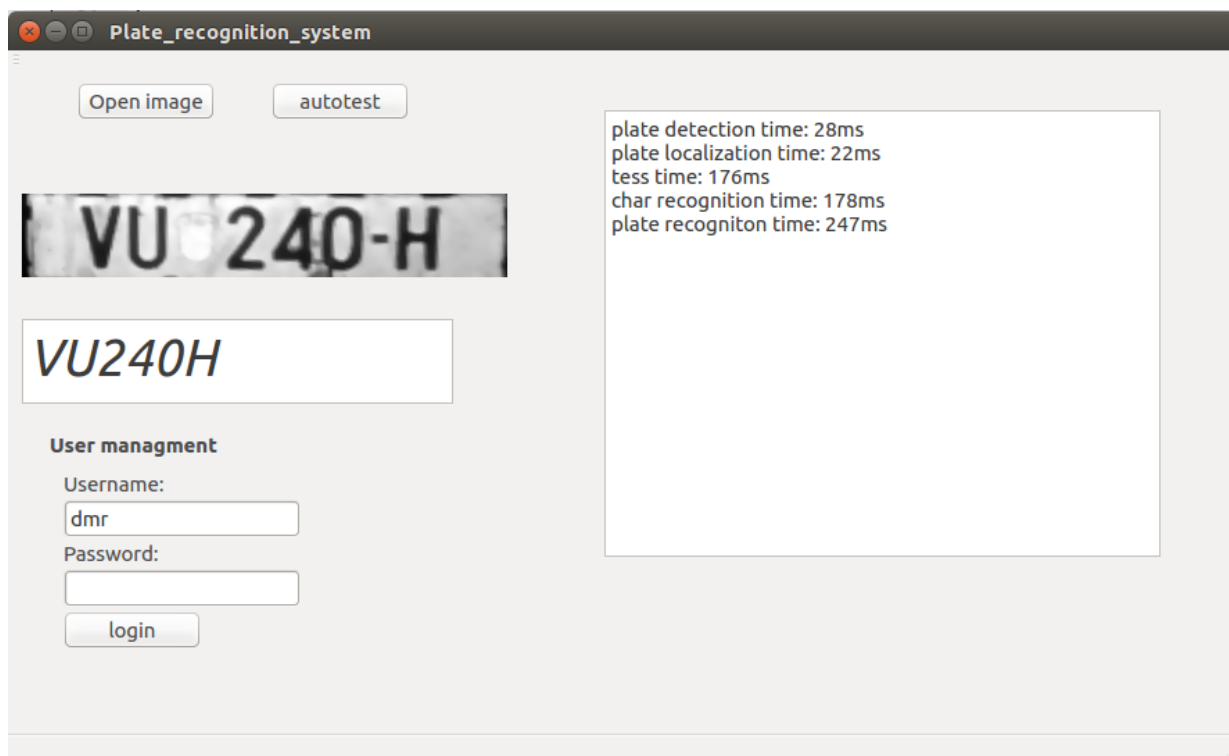
This paper deals with implementing ANPR system for automatic vehicle identification based on number plates. This paper shows approach based on computer vision. The system consists of a Raspberry Pi microcomputer, Raspberry Pi NOIR camera and accompanying software. The software is written using C++ programming language and implemented in QT environment with the OpenCV computer vision library. The application is presented as a series of algorithms which are performed in sequential matter. Algorithms include: algorithm for data preprocessing, algorithm for number plate identification and localization, character segmentation and optical character recognition. Tesseract library is used for optical character recognition. Last step is access control. Application uses integrated SQLite database. Application has accuracy of approximately 99%.

Keywords: ANPR, LPR, computer vision, OpenCV, optical character recognition, Tesseract

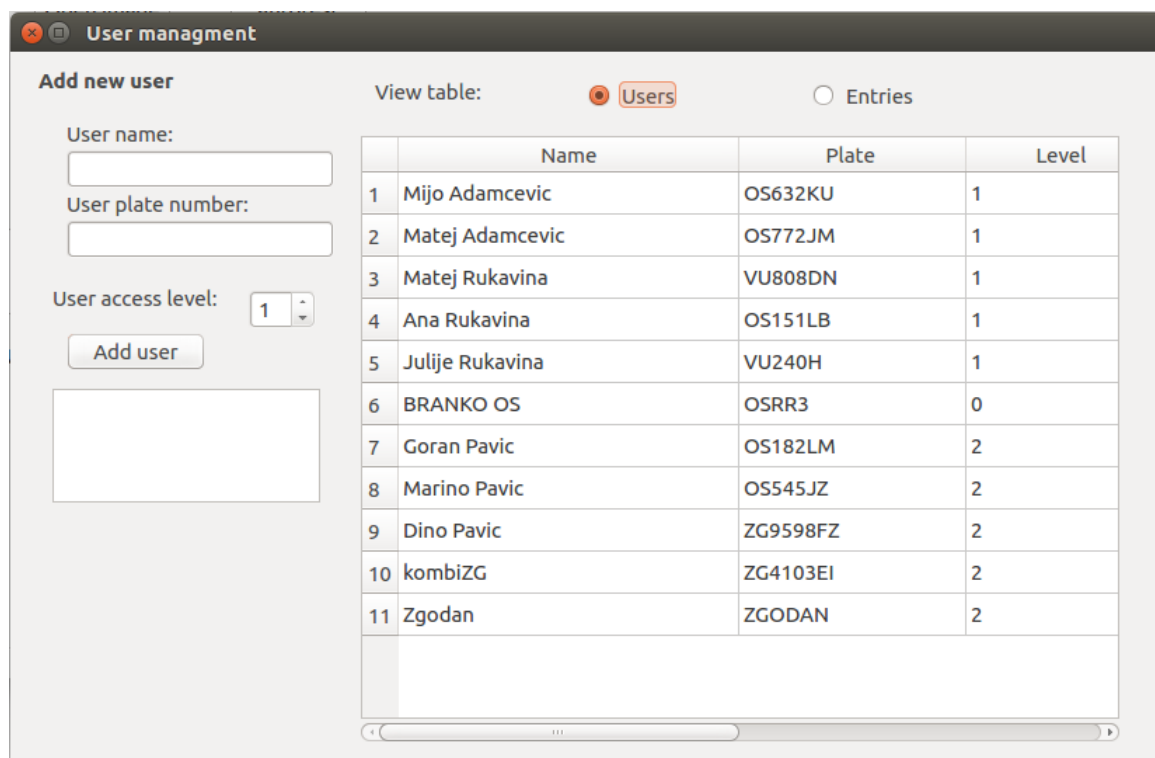
ŽIVOTOPIS

Dominik Martin Rukavina rođen je 9. siječnja 1994. godine u mjestu Ehingen u Njemačkoj. Pohađa osnovnu školu „Ivana Filipovića“ u Osijeku nakon koje upisuje III. gimnaziju u Osijeku i završava 2012. godine. Nakon toga upisuje i završava sveučilišni preddiplomski studij računarstva na „Elektrotehničkom fakultetu Osijek“ i stječe zvanje prvostupnik (baccalaureus) inženjer računarstva (univ. bacc. ing. comp.). Potom upisuje diplomski studij procesnog računarstva na „Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek“. Aktivno govori i piše engleski jezik. Od računalnih vještina vrlo dobro poznaje C, C++, C#, Python i Matlab programske jezike.

PRILOG



Sl. 0.1. Prikaz glavnog korisničkog sučelja



Sl 0.2. Prikaz sučelja za administraciju korisnika uz prikaz tablice korisnika

